

Ein formales Modell für Anwendungen Künstlicher Intelligenz in Automatisierungssystemen

Marvin Schieseck, Philip Topalis, Felix Gehlhoff

Institut für Automatisierungstechnik

Helmut-Schmidt-Universität/Universität der Bundeswehr Hamburg

Hamburg, Deutschland

marvin.schieseck@hsu-hh.de

Alexander Fay

Lehrstuhl für Automatisierungstechnik

Ruhr Universität Bochum

Bochum, Deutschland

alexander.fay@rub.de

Zusammenfassung—Die Integration von Künstlicher Intelligenz (KI) in Automatisierungssysteme wird durch mangelnde Standardisierung im Bereich der Dokumentationen von KI-Anwendungen behindert. Diese Arbeit schlägt ein formales Modell vor, das auf Standards und Ontologien basiert, um eine klare und strukturierte Dokumentation von KI-Anwendungen in Automatisierungssystemen zu ermöglichen. Das vorgeschlagene Informationsmodell für Künstliche Intelligenz in Automatisierungssystemen nutzt Ontologie-Design-Patterns, um verschiedene Aspekte von Automatisierungssystemen und KI-Software abzubilden und zu verknüpfen. Evaluiert durch ein praktisches Beispiel, zeigt das Modell seine Effektivität bei der Verbesserung der Dokumentation und bei der Unterstützung der nachhaltigen Integration von KI in Automatisierungssysteme.

Index Terms—Künstliche Intelligenz, Ontologien, Semantic Web, OWL, Modellierung

I. EINLEITUNG

In den letzten Jahren hat die Integration von Anwendungen der Künstlichen Intelligenz (KI) in technische Systeme wie Automatisierungssysteme erheblich an Dynamik gewonnen [1]. Zahlreiche Anwendungsfälle zeigen bereits, dass durch die Einbindung von KI neue Lösungen ermöglicht oder die Effizienz bestehender Lösungen gesteigert werden konnte [2]. Beispiele hierfür finden sich in den Bereichen Wartung, Qualitätskontrolle und Planung [3]. Trotz dieser vielversprechenden Einsatzmöglichkeiten bleibt die Verbreitung von KI in verschiedenen Industriezweigen relativ gering [4].

Häufig werden KI-Anwendungen im Rahmen von Forschungsprojekten entwickelt und lassen sich wirtschaftlich nicht in die Praxis umsetzen. Dies liegt teilweise daran, dass bestimmte Aspekte von KI-Software – wie die Qualität und Verwaltung der Daten, das Management der Rechenressourcen, die Vertrauenswürdigkeit und die Dokumentation der Software – im Vergleich zu herkömmlicher Automatisierungssoftware besonders herausfordernd sind und die wirtschaftliche Integration und den Betrieb erschweren [4]–[7].

Obwohl einige Aspekte, wie die Datenqualität und Datenverwaltung sowie die Vertrauenswürdigkeit, in den letzten Jahren umfangreich erforscht wurden, wird die Softwaredokumentation von KI-Anwendungen und deren

Auswirkungen auf das Gesamtsystem in verschiedenen Szenarien oft vernachlässigt [6], [7]. Gleichzeitig gibt es einen globalen Trend zur Schaffung neuer gesetzlicher Vorschriften für KI, wie am Beispiel der Europäischen Union mit dem EU Artificial Intelligence Act [8] zu sehen ist. Diese erfordert eine umfassende Analyse der Risiken von KI-Anwendungen und empfiehlt deren Dokumentation. Es kann angenommen werden, dass mit der fortschreitenden Entwicklung solcher Regulierungen eine klare und strukturierte Dokumentation von KI-Anwendungen immer wichtiger werden wird.

Zusätzliche Herausforderungen bei der Dokumentation ergeben sich aus der inhärenten Komplexität sowohl von Automatisierungs- als auch von KI-Systemen. Beide Systeme bestehen in der Regel aus mehreren Hardware- und Softwarekomponenten, die stark miteinander vernetzt und voneinander abhängig sind [9]. Darüber hinaus haben Automatisierungssysteme oft lange Lebenszyklen, die sich über Jahrzehnte erstrecken. Wenn einzelne technische Komponenten innerhalb dieser Systeme aktualisiert oder ersetzt werden, ist eine umfassende Dokumentation erforderlich. Diese kann anschließend genutzt werden, um festzustellen, wie sich Änderungen, wie der Austausch von Sensoren oder Steuerungen auf die KI-Anwendung auswirken. Daher ist eine detaillierte Dokumentation unerlässlich für die Implementierung und den Betrieb von KI-Anwendungen in Automatisierungssystemen.

Es bedarf einer Lösung zur Dokumentation von KI-Anwendungen in Automatisierungssystemen, welche Informationen über die Komponenten des Automatisierungssystems, die KI-Softwarekomponenten sowie den zugrunde liegenden technischen Prozess und deren Interdependenzen und Beziehungen erfasst. Insbesondere wird ein formales Modell zur Beschreibung von KI-Anwendungen in Automatisierungssystemen benötigt [10]. Deshalb wird in diesem Artikel ein formales Modell für KI-Anwendungen in Automatisierungssystemen vorgeschlagen, das auf Standards basiert und Ontologien nutzt.

II. ANFORDERUNGSANALYSE

Die Softwareentwicklung für KI-Anwendungen ist komplexer als für traditionelle Software. Dies umfasst Aspekte wie unklare Systemgrenzen, nicht deklarierte

Datenabhängigkeiten, Konfigurationsprobleme und Veränderungen der externen Umgebung, um nur einige zu nennen. Bemerkenswert ist, dass der Code für KI-Modelle und deren Training oft nur aus wenigen Zeilen Programmcode besteht und somit einen kleinen Teil des Gesamtcodes ausmacht. Der Großteil einer KI-Anwendung bzw. ihres Programmcodes beschäftigt sich hingegen mit Aufgaben wie Automatisierung, Testen, Ressourcenmanagement, Prozessmanagement, sowie Bereitstellung, Sammlung, Speicherung, Übertragung und Verifizierung von Daten. [7]

Basierend auf den dargestellten Herausforderungen und Aspekten ergeben sich folgende Anforderungen (A) für ein formales Modell für KI-Anwendungen in Automatisierungssystemen:

(A1) Beschreibung von Interdependenzen: Das Modell muss Informationen und Interdependenzen zwischen Komponenten des Automatisierungssystems, KI-Softwarekomponenten und dem technischen Prozess erfassen können. Dies ist entscheidend, da KI-Anwendungen in Automatisierungssystemen typischerweise über mehrere Komponenten im technischen System verteilt sind und daher verschiedene Abhängigkeiten abdecken müssen [9].

(A2) Semantisch eindeutig und standardisiert: Das Modell muss semantisch eindeutig sein, damit Experten aus verschiedenen Domänen Informationen klar verstehen, dokumentieren und kommunizieren können. Um dies zu erreichen, sollte der Inhalt und die Terminologie auf Standards basieren, da diese von Expertengruppen entwickelt werden und innerhalb spezifischer Gemeinschaften einen semantischen Konsens darstellen [11].

(A3) Formalisierte Darstellung: Das Modell muss in der Lage sein, die Informationen formalisiert darzustellen, um Wiederverwendbarkeit zu gewährleisten und Mehrdeutigkeiten zu minimieren [10]. Die Formalisierung in Verbindung mit einem herstellerunabhängigen Austauschformat macht das Modell maschinenlesbar und erleichtert die Integration in die vielfältige Tool-Landschaft von Automatisierungssystemen und Softwaretechnik.

(A4) Erweiterbarkeit und Anpassungsfähigkeit: Das Modell muss erweiterbar und anpassungsfähig sein, um Änderungen in Standards, Vorschriften und Gesetzgebungen, insbesondere im sich schnell entwickelnden Bereich der KI, berücksichtigen zu können [10]. Da KI-Regulierungen länderübergreifend variieren und häufig aktualisiert werden, wird das Modell zahlreiche Anpassungen erfordern. Im Gegensatz dazu können die Teile des Modells, die Informationen über Automatisierungssysteme beschreiben, über Jahrzehnte stabil bleiben.

III. STAND DER TECHNIK UND VERWANDTE ARBEITEN

Es wurden drei relevante Forschungsbereiche bezüglich der Dokumentation von KI-Anwendungen identifiziert: 1.) *Datenblätter*, 2.) *Ontologien* und 3.) *grafische Modellierungsansätze*. Im Folgenden werden relevante Arbeiten der jeweiligen Bereiche vorgestellt und hinsichtlich der Anforderungserfüllung analysiert.

A. Informelle Dokumentation mit Datenblättern und Karten

Ein Bereich der Forschung konzentriert sich auf die Erstellung von *Datenblättern*. Diese sind kurze Dokumente mit vordefinierten Kategorien, um relevante Informationen über die KI-Anwendung zu erfassen. Um die relevanten Informationen zu erhalten, verwenden die Autoren eine Reihe vordefinierter Fragen, die von den Entwicklern der KI-Anwendung beantwortet und niedergeschrieben werden müssen. [12]–[15]

Zum Beispiel schlagen Gebru et al. [12] einen Ansatz namens *Datasheets for Datasets* vor, um den Erstellungsprozess, die Verteilung, die Wartung sowie eventuelle Annahmen und Risiken eines Datensatzes zu reflektieren und zu dokumentieren. Inspiriert von den *Datasheets for Datasets* schlagen Mitchell et al. [13] ein Framework namens *Model Cards* vor, um transparente Berichterstattung über trainierte Machine-Learning-Modelle zu fördern. *Model Cards* sind kurze Dokumente, die Benchmarks zur Leistung des Modells unter verschiedenen Bedingungen dokumentieren. Arnold et al. [14] schlagen *FactSheets* vor, um das Vertrauen in KI-Dienste zu erhöhen, indem verschiedene Eigenschaften der KI-Dienste dokumentiert werden, einschließlich der Frage, ob die zur Entwicklung der Dienste verwendeten Daten durch *Datasheets* begleitet werden. Ähnlich schlagen Lavin et al. [15] einen Prozess vor, um die Dokumentation robuster, zuverlässiger und verantwortungsvoller Machine-Learning-Systeme durch sogenannte *Technology Readiness Level Cards* (TLR-Karten) sicherzustellen.

Die Ansätze mit *Datenblättern und Karten* beschränken sich lediglich auf die Beschreibung der KI-Komponenten und der Daten. Eine Dokumentation des technischen Systems, des technischen Prozesses sowie deren Interdependenzen sind nicht vorgesehen (A1). Trotz der Organisation in vordefinierte Kategorien und Fragen erfolgen die Antworten größtenteils im Freitextformat (A3). Folglich hängen Form und Genauigkeit von der Sorgfalt und Erfahrung der Befragten ab [13]. Die Blätter und Karten orientieren sich nicht an Vokabularen und Begriffen von Standards oder Vorschriften (A2). Ihre einfache Struktur erleichtert jedoch eine einfache Erweiterung und Anpassung an verschiedene Anwendungsfälle oder Domänen (A4).

B. Formale Dokumentation mit Ontologien

Das zweite Forschungsgebiet konzentriert sich auf die formale Dokumentation von KI-Anwendungen mithilfe von Ontologien anstelle von Datenblättern. Dieses Forschungsgebiet lässt sich in zwei Hauptbereiche unterteilen: 1.) Dokumentation des Entwicklungsprozesses und 2.) Dokumentation der Modelle. [16], [17]

Der erste Bereich konzentriert sich auf Ontologien zur Unterstützung der Erstellung und Dokumentation des zugrunde liegenden Entwicklungsprozesses, wie von Sinha et al. [16] zusammengefasst. Zum Beispiel schlagen Panov et al. [18] eine Ontologie namens *OntoDM-KDD* vor, um den Wissensentdeckungsprozess basierend auf dem *Cross*

Industry Standard Process for Data Mining (CRISP-DM) darzustellen. Eine weitere Ontologie, die *Data Mining Optimization Ontology* (DMOP) von Keet et al. [19], vereinfacht Entscheidungsfindung und optimiert die Leistung von Data-Mining-Prozessen. Der zweite Bereich fokussiert auf Ontologien, die die Dokumentation von Modellen und Algorithmen unterstützen, insbesondere im Bereich des maschinellen Lernens (ML), wie von Sinha et al. [17] durchgeführt. Zum Beispiel dient die *Exposé*-Ontologie, vorgeschlagen von Vanschoren und Soldatova [20], dazu, Data-Mining-Experimente zu modellieren. Esteves et al. [21] schlagen eine Ontologie namens *MEX Vocabulary* vor, die entwickelt wurde, um ML-Experimente zu beschreiben. Publio et al. [22] entwickeln die *ML-Schema*-Ontologie zur Darstellung und Interaktion von Informationen über ML-Algorithmen, Datensätze und Experimente. Diese auf Ontologien basierenden Ansätze für ML dienen als Grundlage für große Community-Plattformen wie OpenML¹ zum Informationsaustausch über ML-Ansätze [23].

Die auf *Ontologien* basierenden Ansätze sind von Natur aus formalisiert (A3). Die meisten Ansätze verwenden die *Web Ontology Language*² (OWL) als herstellerunabhängiges Format (A3). Weder die Ontologien, die sich auf Data-Mining-Prozesse konzentrieren, noch diejenigen, die sich auf ML-Algorithmen konzentrieren, berücksichtigen den technischen Prozess, das technische System, die KI-Komponenten und deren Interdependenzen (A1). Darüber hinaus orientieren sich die Ontologien nicht an Standards oder Vorschriften (A2). Die meisten Ontologien sind zudem untereinander semantisch inkonsistent. Sie bestehen aus großen, monolithischen Blöcken mit diversen Klassen und Beziehungen, was in der Praxis Herausforderungen mit sich bringt (A4), obwohl sie in der Theorie einfach erweiterbar und anpassbar sind.

C. Semiformale Dokumentation mit grafischen Modellen

Das dritte Forschungsgebiet konzentriert sich auf den Einsatz von grafischen Modellierungsansätzen. Ein grafisches Modell kann den Kern eines Problems auf eine semiformale und verständliche Weise für verschiedene Stakeholder und Experten darstellen. Ein spezifischer Ansatz für die grafische Darstellung von KI-Systemen wurde von Kaymakci et al. [24] vorgestellt, der sich darauf konzentriert, die Beziehungen zwischen Datenquellen, Datenzielen und Datenverarbeitungskomponenten darzustellen. Auf dieser Grundlage wurde die *Graphical Modeling Language for Artificial Intelligence Applications in Automation Systems* (GML-AIAAS³) [25] vorgeschlagen, die KI-Systeme innerhalb von Automatisierungssystemen darstellen kann. Unter Verwendung der Systemtechnik-Prinzipien, wie sie von Haberfellner et al. [26] beschrieben wurden, kategorisiert diese Modellierungssprache das gesamte System in drei primäre Elementtypen: 1.) Systemkomponenten,

2.) Systemfunktionen und 3.) Systembeziehungen. Die Beziehungen (z. B. Kommunikation, Zuweisung und Produkt-/Material-/Energiefluss) etablieren die Verbindungen zwischen den Systemkomponenten (z. B. Sensor, Aktor, Controller, Cloud) und den Systemfunktionen (z. B. Trainieren, Aufzeichnen, Speichern, Inferieren). Um diese Elementtypen eindeutig zu repräsentieren, definiert die GML-AIAAS eine Reihe von Symbolen und eine Syntax. Zusätzlich existiert für GML-AIAAS ein Metamodell³ zur weiteren Formalisierung.

Der Ansatz von Schieseck et al. [25] ermöglicht es, Interdependenzen zwischen technischem System, technischem Prozess und KI-Funktionen durch eine definierte Symbolik und Syntax darzustellen (A1). Durch die Verwendung des bereitgestellten Metamodells kann die Symbolik in ein herstellernerutrales Format wie XML oder JSON transformiert und formalisiert werden (A3). Allerdings orientiert sich dieser Ansatz nicht an Standards (A2). Aufgrund der einfachen Struktur des Metamodells kann der Inhalt leicht erweitert und angepasst werden (A4).

D. Diskussion der verwandten Arbeiten

Zusammenfassend erfüllt keiner der bestehenden Ansätze vollständig die spezifizierten Anforderungen zur Bewältigung des identifizierten Handlungsbedarfs. Die Datenblätter sind nicht formal und es mangelt an semantischer Eindeutigkeit. Die bestehenden Ontologien berücksichtigen nicht die Interdependenzen zwischen dem technischen System und dem KI-System und sind untereinander inkonsistent. Die grafischen Modelle sind nicht hinreichend formalisiert. Keiner der bestehenden vorgestellten Ansätze berücksichtigt die Terminologie oder Struktur der existierenden Standards für KI. Daher besteht Bedarf an einem neuen und anforderungsgerechten Ansatz, welcher im folgenden Abschnitt vorgestellt wird.

IV. FORMALE BESCHREIBUNG VON INDUSTRIELLEN KI-ANWENDUNGEN

In diesem Abschnitt wird ein neues Informationsmodell für Künstliche Intelligenz in Automatisierungssystemen (*engl. Artificial Intelligence in Automation Systems*, kurz AIAS⁴) vorgestellt.

Es basiert auf Ontologien, da diese eine Möglichkeit bieten, semantisch angereicherte und formalisierte Informationsmodelle zu erstellen. Darüber hinaus ermöglicht die Verwendung von Ontologien in Kombination mit formalen Beschreibungssprachen des Semantic Web, wie z. B. OWL, die Nutzung von Reasoning, Querying und das Anwenden von Regelsprachen. Um sicherzustellen, dass das Informationsmodell leicht erweitert und angepasst werden kann, wird es nicht als eine einzige monolithische Ontologie ausgeführt. Stattdessen werden kleine und unabhängige Ontologien verwendet, welche als „Ontology Design Patterns“ (ODPs) bezeichnet werden [27]. Diese ODPs sind

¹<https://www.openml.org/>

²<https://www.w3.org/OWL/>

³<https://github.com/schiesem/GML-AIAAS>

⁴<https://github.com/schiesem/aias-information-model>

auf der obersten Ebene über eine „Alignment-Ontologie“ miteinander verbunden, die als übergreifende Struktur des AIAS-Informationsmodells dient. Um die Semantik weiter zu verbessern, basiert jedes ODP auf einem Standard [11]. Die verwendeten ODPs werden in zwei Kategorien eingeteilt, um verschiedene Aspekte zu beschreiben:

- **Technisches System und Technischer Prozess:** Diese Kategorie umfasst ODPs, die Begriffe und Beziehungen enthalten, um die Struktur des technischen Systems und die zugrunde liegenden technischen Prozesse zu beschreiben.
- **Künstliche Intelligenz und Daten:** Diese Kategorie besteht aus ODPs, die Begriffe und Beziehungen enthalten, um die KI-Komponenten und deren Funktionalitäten zu beschreiben.

A. Beschreibung des technischen Systems und Prozesses

Die erste Anforderung (A1) betont die Notwendigkeit, die technischen Systemaspekte zu beschreiben, einschließlich der technischen Komponenten und ihrer zugrunde liegenden Prozesse. Die Konzepte, die in der formalisierten Prozessbeschreibung nach VDI 3682 [28] definiert sind, bieten einen standardisierten Rahmen zur Beschreibung verschiedener technischer Prozesse und der zugehörigen Systemstruktur. Nach der VDI 3682 beinhaltet ein Prozess die Umwandlung von Eingaben in Ausgaben, die von einem Prozessoperator mithilfe einer technischen Ressource ausgeführt wird. Diese technische Ressource führt dann den Prozess durch. In einem weiteren Sinne kann eine technische Ressource als fähig angesehen werden, spezifische Funktionen (z. B. Prozesse) zu implementieren, und kann als abstrakte Beschreibung der Systemhardware dienen. Es ist jedoch notwendig, die VDI 3682 um zwei technische Aspekte zu ergänzen, die von der VDI 3682 selbst nicht im Detail abgedeckt werden. Erstens fehlt es der VDI 3682 an Spezifität hinsichtlich verschiedener Arten von technischen Ressourcen. Die *ECLASS*⁵ Spezifikation adressiert diese Lücke, indem sie semantisch eine Vielzahl von Klassen und Individuen technischer Ressourcen definiert, darunter Sensoren, Aktoren, Steuerungen, Computer sowie umfassendere Entitäten wie Rechenzentren oder Cloud-Services. Zusätzlich bietet die *Semantic Sensor Network Ontology*⁶ (SSN) eine alternative Möglichkeit zur Spezifikation von Sensoren und Aktoren und stellt ein umfassendes Vokabular zur Beschreibung von Sensor- und Aktuator-Fähigkeiten bereit, falls erforderlich.

Zweitens spezifiziert VDI 3682 nicht die Kommunikation zwischen verschiedenen technischen Ressourcen. Ein weit verbreiteter Standard zur Beschreibung solcher Kommunikationen zwischen technischen Systemen wird durch die ISO 7498 [30] bereitgestellt. Dieser Standard basiert auf einem siebenstufigen Kommunikationsmodell namens *Open Systems Interconnection* (OSI) Modell. Unter Verwendung dieses OSI-Modells kann eine Kommunikationsverbindung

über die Schichten hinweg, vom physikalischen Level bis hin zum Anwendungslevel, spezifiziert werden.

B. Beschreibung der Künstlichen Intelligenz und Daten

Zusätzlich zu den technischen Aspekten betont Anforderung 1 (A1) die Notwendigkeit, die KI-Komponenten und die verwendeten Daten zu beschreiben. Die ISO 22989 [31] bietet geeignete Konzepte und Terminologie für KI. Dieser Standard ist um drei übergeordnete Aspekte strukturiert: 1.) KI-Komponenten und KI-Funktionen, 2.) KI-Algorithmen und 3.) Daten. Aufgrund der Komplexität der ISO 22989 ist es hilfreich, sie in verschiedene Betrachtungsweisen für jeden Aspekt zu unterteilen.

Im ersten Aspekt werden verschiedene Arten von KI (z. B. symbolisch oder subsymbolisch), Aufgaben (z. B. Klassifikation, Clustering, Regression, Generierung), Systemdesigns (z. B. Cloud, Edge, Hybrid), deren Komponenten und Funktionen (z. B. Datenaufbereitung, Training, Validierung, Evaluation, Inferenz) definiert.

Der zweite Aspekt beschreibt die Semantik und Beziehungen von maschinellen Lernmodellen, maschinellen Lernalgorithmen und Lernarten in Bezug auf die zuvor definierten Funktionen. Zusätzlich werden Modellparameter und Hyperparameter festgelegt.

Der dritte Aspekt beschreibt die Semantik und Beziehungen zwischen Daten und Datensätzen. Neben der Definition der Daten selbst werden auch die Funktionen des Speicherns von Daten in einem Datenspeicher und der Abruf von Daten aus einer Datenquelle beschrieben. Darüber hinaus werden verschiedene Arten von Datensätzen definiert, wie z. B. Trainings-, Evaluierungs-, Produktions- und Testdaten.

C. Beschreibung der Alignment-Ontologie

Bis zu diesem Punkt beschreiben die ODPs die jeweiligen Elemente unabhängig voneinander. Auf der einen Seite gibt es ODPs, welche die technischen Prozesse, die technischen Systeme und die Kommunikation beschreiben, wie zum Beispiel die VDI 3682, ISO 7498 und *ECLASS*. Auf der anderen Seite gibt es ODPs, die die KI-Systeme, die KI-Komponenten mit ihren Funktionen und die Daten beschreiben, wie zum Beispiel ISO 22989.

Jedoch ist es zur Erstellung eines Informationsmodells, das in der Lage ist, KI-Anwendungen innerhalb von Automatisierungssystemen zu beschreiben, notwendig, Verbindungen zwischen den beiden Kategorien und ihren jeweiligen ODPs herzustellen. Um dies zu erreichen, wird eine Alignment-Ontologie erstellt, welche die Inhalte der jeweiligen ODPs miteinander verbindet. Diese Alignment-Ontologie bildet das eigentliche AIAS-Informationsmodell.

Die AIAS-Ontologie wird erstellt, indem alle zuvor genannten ODPs über `owl:import` Anweisungen importiert werden. Durch diesen Ansatz bleiben alle importierten Ontologien in ihrem eigenen Namensraum (z. B. VDI3682:, ISO22989, ISO7489:), während die

⁵<https://eclass.eu/>

⁶<https://www.w3.org/TR/vocab-ssn/>

Alignment-Ontologie ihren eigenen Namensraum definiert, der als *AIAS*: bezeichnet wird.

Das Metamodell³ aus dem grafischen Modellierungsansatz in [25] bildet die grundlegende Struktur des AIAS-Informationsmodells und dient als Grundlage zur Beschreibung von KI in Automatisierungssystemen. Dieses Metamodell umfasst die Kernklassen *Funktion*, *Komponente* und *Relation*. Ein Teil dieser Kernklassen sowie einige Unterklassen werden sukzessive durch importierte Klassen aus den ODPs der Standards ersetzt, erweitert oder gleichgestellt. Dieser iterative Prozess ermöglicht die Integration spezifischen Domänenwissens und gewährleistet die Integration von etablierten Standards. Das zentrale Konzept der AIAS-Alignment-Ontologie mit den zugrundeliegenden Elementen ist in einem Klassendiagramm in Abb. 1 abgebildet.

Da die jeweiligen Klassen aus den ODPs importiert wurden, werden auch weitere Beziehungen, die in den ODPs beschrieben sind, in AIAS importiert und integriert. Beispielsweise werden Beziehungen zwischen Training, Modell, Inferenz und Daten eingebunden. Dadurch wird eine detailliertere Modellierung von KI-Anwendungen in Automatisierungssystemen ermöglicht.

V. ANWENDUNG AM FALLBEISPIEL

Zur Evaluierung des AIAS-Informationsmodells wurde ein exemplarisches industrielles Fallbeispiel einer KI-Anwendung modelliert. Der Anwendungsfall war Teil des Forschungsprojekts EKI⁷ und wurde in Zusammenarbeit mit einem Industriepartner spezifiziert und implementiert. Die Modellierung erfolgte durch Instanziierung und Verbindung der anwendungsfallspezifischen Informationen. Auf diese Weise wurde ein anwendungsfallspezifischer Wissensgraph

⁷<https://dtecbw.de/home/forschung/hsu/projekt-eki>

erzeugt, welcher die instanzspezifischen Informationen semantisch einheitlich dokumentiert. Dieser Graph ist in Abb. 2 abgebildet.

A. Vorstellung des Fallbeispiels

Der Anwendungsfall des Fallbeispiels ist ein Stanzprozess, der von einer Stanzmaschine durchgeführt wird. Das Hauptgeschäftsziel des Anwendungsfalls besteht darin, die Wartungskosten für die Stanzmaschine zu minimieren.

Die Stanzmaschine wird verwendet, um Teile aus blanken Metallblechen für die Automobilindustrie herzustellen. Sie besteht aus einem Traggestell, einer festen Untermatrize und einer beweglichen Obermatrize. Die Obermatrize wird von einem Elektromotor betrieben, der auf dem Traggestell montiert ist, wobei die Antriebskraft über einen Antriebsriemen übertragen wird. Die Position der Obermatrize wird von einem Positionsgeber überwacht. Im Laufe der Zeit führt der Verschleiß des Antriebsriemens zu einer ungenauen Steuerung der Obermatrize, wodurch die hergestellten Teile von den strengen Toleranzanforderungen abweichen. Derzeit wird der Antriebsriemen in regelmäßigen Abständen ausgetauscht, was zu hohen Wartungskosten führt. Daher besteht das Hauptgeschäftsziel darin, die Wartungskosten zu senken, indem der Zustand des Antriebsriemens kontinuierlich klassifiziert wird.

Experimente des Industriepartners zeigen, dass ein abgenutzter Antriebsriemen Schwingungen in der Positionierung der Obermatrize verursacht. Mit diesem Erkenntnisgewinn können Daten, die während des Stanzprozesses von Sensoren aufgezeichnet werden, genutzt werden, um den Zustand des Antriebsriemens zu inferieren.

Die Sensordaten werden über ein Bussystem an einen Controller übertragen. Der Controller kommuniziert über Ethernet mit einem Edge-Gerät, während das Edge-Gerät

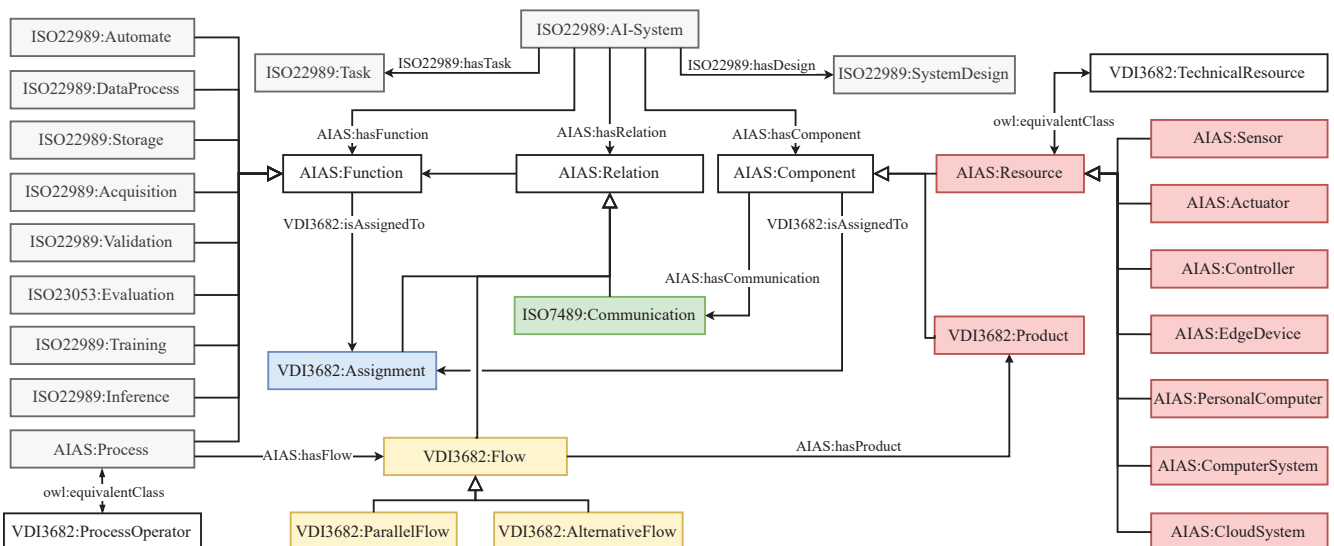


Abbildung 1: Kernkonzept der Alignment-Ontologie AIAS, welches die Verbindung verschiedener Standards durch Ontologie-Design-Patterns (ODPs) zeigt. Die detaillierten Inhalte der ODPs sind nicht dargestellt, um die Verständlichkeit zu erhöhen. Rot kennzeichnet technische Ressourcen oder Produkte. Blau kennzeichnet Zuweisungen. Grün kennzeichnet Kommunikationen. Grau kennzeichnet Systemfunktionen und -eigenschaften. Abbildung in Anlehnung an [29].

selbst über das Internet mit einer Cloud kommuniziert. In der Cloud wird das Modell trainiert und für die Inferenz bereitgestellt. Ein künstliches neuronales Netzwerk (KNN) wird als Modell verwendet, um die Sensordaten zu analysieren und den Zustand des Riemens zu klassifizieren.

B. Durchführung der Modellierung

Der Anwendungsfall wurde erfolgreich unter Verwendung der AIAS-Alignment-Ontologie und der Software *Protégé*⁸ modelliert. Zum Beispiel wurde die Kommunikation zwischen dem Edge-Gerät und dem Controller mit einer Instanz der Klasse `ISO7489:Communication` modelliert, die mit Instanzen der entsprechenden technischen Ressourcen, `AIAS:EdgeDevice` und `AIAS:Controller`, verbunden ist. Ebenso wurden das Training in der Cloud und die Bereitstellung des trainierten KNNs mit Instanzen der Klasse `VDI3682:Assignment` modelliert, die jeweils mit Instanzen der Funktionen `ISO22989:Training` und `ISO22989:Inference` verbunden sind. Während des Modellierungsprozesses wurden Elemente des ISO 22989 ODPs verwendet, um weitere Details bereitzustellen, wie Instanzen der Klassen `ISO22989:Modelparameter`, `ISO22989:Hyperparameter` und `ISO22989:Data`. Ein vereinfachter Auszug des resultierenden Wissensgraphs ist in Abb. 2 dargestellt.

⁸<https://protege.stanford.edu/>

C. Diskussion der Ergebnisse

Das AIAS-Informationsmodell ermöglicht die Beschreibung von KI-Anwendungen in Automatisierungssystemen durch die Fokussierung auf die Interdependenzen zwischen Komponenten des Automatisierungssystems, KI-Komponenten und technischen Prozessen, wie am Beispiel der Modellierung des Anwendungsfalls demonstriert (A1). Die Verwendung von Begriffen aus Standards wie der ISO 22989, ISO 7489 oder VDI 3682 gewährleistet eine klare und eindeutige Semantik (A2). Darüber hinaus können bei Bedarf die Semantiken der Komponenten des Automatisierungssystems durch den Import von ECLASS oder UNSPSC in AIAS weiter angereichert werden. Die Nutzung von Ontologien in Kombination mit OWL gewährleistet die formalisierte Erfassung von Informationen (A3). OWL als standardisierte Repräsentationssprache, gepflegt und definiert durch das W3C, macht den Ansatz maschinenlesbar und herstellerunabhängig (A3). Die AIAS-Ontologie bestehend aus mehreren unabhängigen ODPs und bietet Erweiterbarkeit und Anpassungsfähigkeit (A4). Weitere ODPs können einfach importiert und integriert werden, um detailliertere Beschreibungen zu ermöglichen. Aktualisierungen von Standards erfordern lediglich die Aktualisierung des relevanten ODPs, nicht der gesamten AIAS-Ontologie.

Zusammenfassend erfüllt das AIAS-Informationsmodell die genannten Anforderungen (A1-A4) und ermöglicht die Modellierung und Dokumentation von KI-Anwendungen für Automatisierungssysteme.

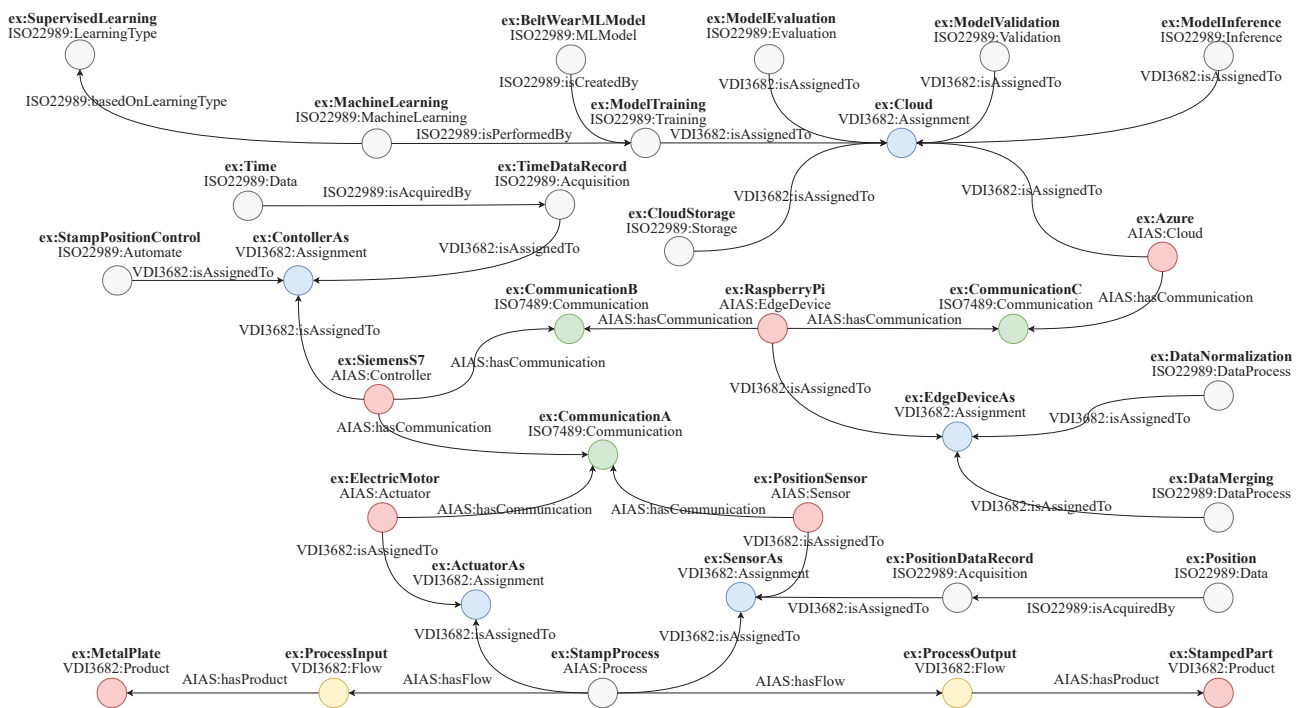


Abbildung 2: Ausschnitt aus dem resultierenden Wissensgraph des Fallbeispiels. Rote Knoten sind technische Ressourcen oder Produkte. Blaue Knoten entsprechen den Zuweisungen. Grüne Knoten sind Kommunikationsbeziehungen. Grauen Knoten sind Systemfunktionen und deren Detaillierung.

AIAS ermöglicht zudem Abfragen basierend auf Querying zur einfachen Extraktion spezifischer Informationen. Darüber hinaus ist die Formulierung komplexer Sachverhalte durch Regeln möglich sowie die Generierung neuen Wissens mithilfe von Reasoning. Trotz dieser Vorteile gibt es einige Nachteile des Ansatzes. Zunächst ist ein detailliertes Verständnis des AIAS-Informationsmodells, der AIAS-Ontologie sowie ihrer ODPs erforderlich, bevor mit der Modellierung begonnen werden kann. Ein weiterer Nachteil ist die Abhängigkeit von Werkzeugen wie Protégé, deren Nutzung ebenfalls Einarbeitungszeit erfordert.

VI. ZUSAMMENFASSUNG UND AUSBLICK

Dieser Artikel stellt ein formales Modell zur Beschreibung von Anwendungen Künstlicher Intelligenz (KI) in Automatisierungssystemen vor. Das Konzept ermöglicht die Erstellung eines Wissensgraphen, der die Komponenten des Automatisierungssystems, die KI-Elemente, die technischen Prozesse und ihre Wechselwirkungen umfasst und dokumentiert.

Das formale Modell wurde unter Verwendung von Ontologien implementiert, wobei die Strategie verfolgt wurde, mehrere kleinere Ontologie-Design-Patterns (ODPs) auf Basis von Standards zu nutzen, anstatt eine einzelne große und monolithische Ontologie zu konstruieren. Diese modularen ODPs werden kombiniert, um eine erweiterbare und anpassbare Alignment-Ontologie namens AIAS-Ontologie zu bilden. Speziell wird ein ODP basierend auf dem ISO 22989 Standard genutzt, um Informationen über KI-Elemente zu beschreiben, während ein ODP basierend auf der VDI 3682 für Informationen über das Automatisierungssystem, technische Prozesse und Komponenten verwendet wird. Zusätzlich wird ein ODP, abgeleitet aus der ISO 7489, erstellt, um die Kommunikation innerhalb des KI- bzw. Automatisierungssystems darzustellen. Der Beitrag zeigt die Vorteile von AIAS anhand eines exemplarischen Anwendungsfalls im Bereich eines Stanzprozesses auf.

Zusammenfassend ermöglicht das Modellieren mit AIAS die formale Beschreibung von KI-Anwendungen für industrielle Anwendungsfälle. Folglich hat AIAS das Potenzial, die Dokumentation zu standardisieren und die Integration, den Betrieb und die Wartung von KI-Anwendungen in Automatisierungssystemen zu optimieren.

Für die Zukunft ist geplant, AIAS um weitere Subklassen zu erweitern, um den Umfang der Beschreibung von KI-Elementen zu erhöhen. Darüber hinaus beabsichtigen wir, Regeln und Einschränkungen zu erstellen, um den Dokumentationsprozess von KI-Anwendungen weiter zu verbessern. Zum Beispiel könnten Regeln verwendet werden, um automatisch den Typ eines KI-Systems gemäß gesetzlicher Vorschriften zu klassifizieren. Zusätzlich zur Erweiterung von AIAS ist die Entwicklung eines spezialisierten Modellierungstools geplant, um den Modellierungsprozess zu optimieren und die Einstiegshürden für die Nutzung zu senken.

DANKSAGUNG

Diese Forschungsarbeit aus dem Projekt EKI⁷ wird durch dtec.bw – Zentrum für Digitalisierungs- und Technologieforschung der Bundeswehr gefördert. dtec.bw wird von der Europäischen Union – NextGenerationEU finanziert.

LITERATUR

- [1] "Harnessing the AI Revolution in Industrial Operations," World Economic Forum, Technischer Bericht, Oct. 2023. [Online]. Available: https://www3.weforum.org/docs/WEF_Harnessing_the_AI_Revolution_in_Industrial_Operations_2023.pdf
- [2] R. S. Peres, X. Jia, J. Lee *et al.*, "Industrial Artificial Intelligence in Industry 4.0-Systematic Review, Challenges, and Outlook," *IEEE Access*, Band 8, 2020, doi: 10.1109/ACCESS.2020.3042874.
- [3] "Artificial Intelligence Use cases," Technischer Bericht TR 24030, 2024.
- [4] M. Merkel-Kiss und J. Von Garrel, "Systematische Literaturanalyse zum KI-Einsatz und KI-basierten Geschäftsmodellen in produzierenden kleinen und mittleren Unternehmen [Systematic Literature Analysis on the Use of AI and AI-based Business Models in Small and Medium-sized Manufacturing Companies]," *Zeitschrift für Arbeitswissenschaft*, Band 77, Nr. 3, pp. 453–468, 2023, doi: 10.1007/s41449-022-00323-9.
- [5] M. W. Hoffmann, R. Drath, und C. Ganz, "Proposal for Requirements on Industrial AI solutions," in *Machine Learning for Cyber Physical Systems*. Springer Berlin Heidelberg, 2021, pp. 63–72, doi: 10.1007/978-3-662-62746-4_7.
- [6] A. Paleyes, R.-G. Urma, und N. D. Lawrence, "Challenges in Deploying Machine Learning: A Survey of Case Studies," *ACM computing surveys*, Band 55, Nr. 6, pp. 1–29, 2022, doi: 10.1145/3533378.
- [7] D. Sculley, G. Holt, D. Golovin *et al.*, "Hidden Technical Debt in Machine Learning Systems," in *Proceedings of the 28th International Conference on Neural Information Processing Systems - Volume 2*, Reihe NIPS'15. MIT Press, 2015, p. 2503–2511.
- [8] European Parliament, "P9 TA(2024)0138 Proposal for a Regulation of the European Parliament and of the Council laying down harmonised rules on artificial intelligence (Artificial Intelligence Act) and amending certain Union legislative acts," Jan. 2024. [Online]. Available: <https://artificialintelligenceact.eu/wp-content/uploads/2024/02/AIA-Trilogue-Coreper.pdf>
- [9] C. P. Filho, E. Marques, V. Chang *et al.*, "A Systematic Literature Review on Distributed Machine Learning in Edge Computing," *Sensors*, Band 22, 2022, doi: 10.3390/s22072665.
- [10] "Modellierung- und Simulationsbedarfe der intelligenten Fabrik," Forschungsbeirat der Plattform Industrie 4.0 / acatech - Deutsche Akademie der Technikwissenschaften, Technischer Bericht, Dez. 2021. [Online]. Available: <https://www.acatech.de/publikation/modellierungs-und-simulationsbedarfe-der-intelligenten-fabrik-expertise/download-pdf?lang=de>
- [11] C. Hildebrandt, A. Köcher, C. Küstner *et al.*, "Ontology Building for Cyber-Physical Systems: Application in the Manufacturing Domain," *IEEE Transactions on Automation Science and Engineering*, Band 17, Nr. 3, pp. 1266–1282, 2020, doi: 10.1109/TASE.2020.2991777.
- [12] T. Gebru, J. Morgenstern, B. Vecchione *et al.*, "Datasheets for datasets," *CoRR*, 2018, doi: arXiv:1803.09010v1.
- [13] M. Mitchell, S. Wu, A. Zaldivar *et al.*, "Model Cards for Model Reporting," in *Proceedings of the Conference on Fairness, Accountability, and Transparency*, Reihe FAT* '19. New York, NY, USA: Association for Computing Machinery, 2019, p. 220–229, doi: 10.1145/3287560.3287596.
- [14] M. Arnold, R. K. E. Bellamy, M. Hind *et al.*, "FactSheets: Increasing Trust in AI Services Through Supplier's Declarations of Conformity," *IBM Journal of Research and Development*, Band 63, Nr. 4/5, pp. 6:1–6:13, 2019, doi: arXiv:1808.07261.
- [15] A. Lavin, C. M. Gilligan-Lee, A. Visnjic *et al.*, "Technology readiness levels for machine learning systems," *Nature Communications*, Band 13, Nr. 1, p. 6039, 2022, doi: 10.1038/s41467-022-33128-9.
- [16] P. K. Sinha, S. B. Gajbe, S. Debnath *et al.*, "A Review of Data Mining Ontologies," *Data Technologies and Applications*, Band 56, Nr. 2, pp. 172–204, 2022, doi: 10.1108/DTA-04-2021-0106.
- [17] P. K. Sinha, S. B. Gajbe, K. Chakraborty *et al.*, "A Review of Machine Learning Ontologies," *International Journal of Information*

- Dissemination and Technology*, Band 11, Nr. 4, pp. 158–164, 2021, doi: 10.5958/2249-5576.2021.00027.3.
- [18] P. Panov, L. Soldatova, und S. Džeroski, “OntoDM-KDD: Ontology for Representing the Knowledge Discovery Process,” in *Discovery Science*. Springer Berlin Heidelberg, pp. 126–140, doi: 10.1007/978-3-642-40897-7_9.
- [19] C. M. Keet, A. Ławrynowicz, C. Amato *et al.*, “The Data Mining OPTimization Ontology,” Band 32, pp. 43–53, doi: 10.1016/j.webssem.2015.01.001.
- [20] J. Vanschoren und L. Soldatova, “Exposé: An Ontology for Data Mining Experiments,” in *International workshop on third generation data mining: Towards service-oriented knowledge discovery (SoKD-2010)*, 2010, pp. 31–46.
- [21] D. Esteves, D. Moussallem, C. B. Neto *et al.*, “MEX Vocabulary: A Lightweight Interchange Format for Machine Learning Experiments,” in *Proceedings of the 11th International Conference on Semantic Systems*, 2015, pp. 169–176, doi: 10.1145/2814864.2814883.
- [22] G. C. Publio, D. Esteves, A. Ławrynowicz *et al.*, “ML-Schema: Exposing the Semantics of Machine Learning with Schemas and Ontologies,” 2018, doi: arXiv:1807.05351.
- [23] J. Vanschoren, J. N. Van Rijn, B. Bischl *et al.*, “OpenML: Networked Science in Machine Learning,” *ACM SIGKDD Explorations Newsletter*, Band 15, Nr. 2, pp. 49–60, 2014, doi: 10.1145/2641190.2641198.
- [24] C. Kaymakci, S. Wenninger, und A. Sauer, “A Holistic Framework for AI Systems in Industrial Applications,” in *Innovation Through Information Systems*. Springer International Publishing, 2021, doi: 10.1007/978-3-030-86797-3_6.
- [25] M. Schieseck, P. Topalis, und A. Fay, “A Graphical Modeling Language for Artificial Intelligence Applications in Automation Systems,” in *2023 IEEE 21st International Conference on Industrial Informatics (INDIN)*, Lemgo, DE, 2023, doi: 10.1109/INDIN51400.2023.10217890.
- [26] R. Haberfellner, P. Nagel, M. Becker *et al.*, *Systems Engineering*. Springer, 2019, doi: 10.1007/978-3-030-13431-0.
- [27] A. Gangemi und V. Presutti, “Ontology Design Patterns,” in *Handbook on ontologies*. Springer, 2009, pp. 221–243, doi: 10.1007/978-3-540-92673-3_10.
- [28] *Formalised Process Descriptions*, Verein Deutscher Ingenieure e.V. (VDI) Standard 3682, 2015.
- [29] M. Schieseck, P. Topalis, L. Reinpold *et al.*, “A Formal Model for Artificial Intelligence Applications in Automation Systems,” in *2024 IEEE 29th International Conference on Emerging Technologies and Factory Automation (ETFA)*, Padova, IT, 2024.
- [30] *Open Systems Interconnection*, International Organization for Standardization (ISO) Standard 7498, 1996.
- [31] *Artificial Intelligence Concepts and Terminology*, International Organization for Standardization (ISO) Standard 22989, 2022.